Learning signal processing in Persian language

Step 9: Empirical Mode Decomposition

ساناز جواهریان

دانش‌آموخته کارشناسی ارشد مهندسی پزشکی

دانشکده مهندسی برق و کامپیوتر دانشگاه تهران

EMD یک الگوریتم پرکاربرد برای آنالیز سیگنال های غیر خطی و غیر ایستا میباشد.

این روش مبتنی بر تجزیه ی سیگنال به IMF[1] تشکیل دهنده اش میباشد،ویژگی IMF ها این است که هر یک دارای فرکانس لحظه ای معنی داری هستند.

شروط لازم برای اینکه یک سیگنال به عنوان IMF (دارای فرکانس لحظه ای معنی دار) انتخاب شود به صورت زیر است:

1-در طول کل داده های توابع، تعداد اکسترموم ها و تعداد گذر از صفر ها مساوی باشد یا تعدادشان حداکثر یکی اختلاف داشته باشد.

2-در هر نقطه،میانگین پوش بالایی و پوش پایینی صفر باشد.

در حالت عادی یک سیگنال های حقیقی دارای شرایط IMF نبوده و باید آنها را به وسیله ی الگوریتم Sifting Process به توابع مد ذاتی که همان IMFها هستند، تبدیل کرد.

مراحل فرآیند Sifting Process برای سیگنال x(t) به صورت زیر است:

1-تعیین تمامی اکسترموم های نسبی سیگنال x(t) (ماکسیموم ها و مینیموم ها)

2-بدست آوردن پوش بالا و پوش پایین به وسیله ی درون یابی

---

[1] Intrinsic Mode Functions

3-محاسبه ی میاگین پوش بالا و پوش پایین

4-تفاضل میانگین پوش بالا و پوش پایین از سیگنال اصلی

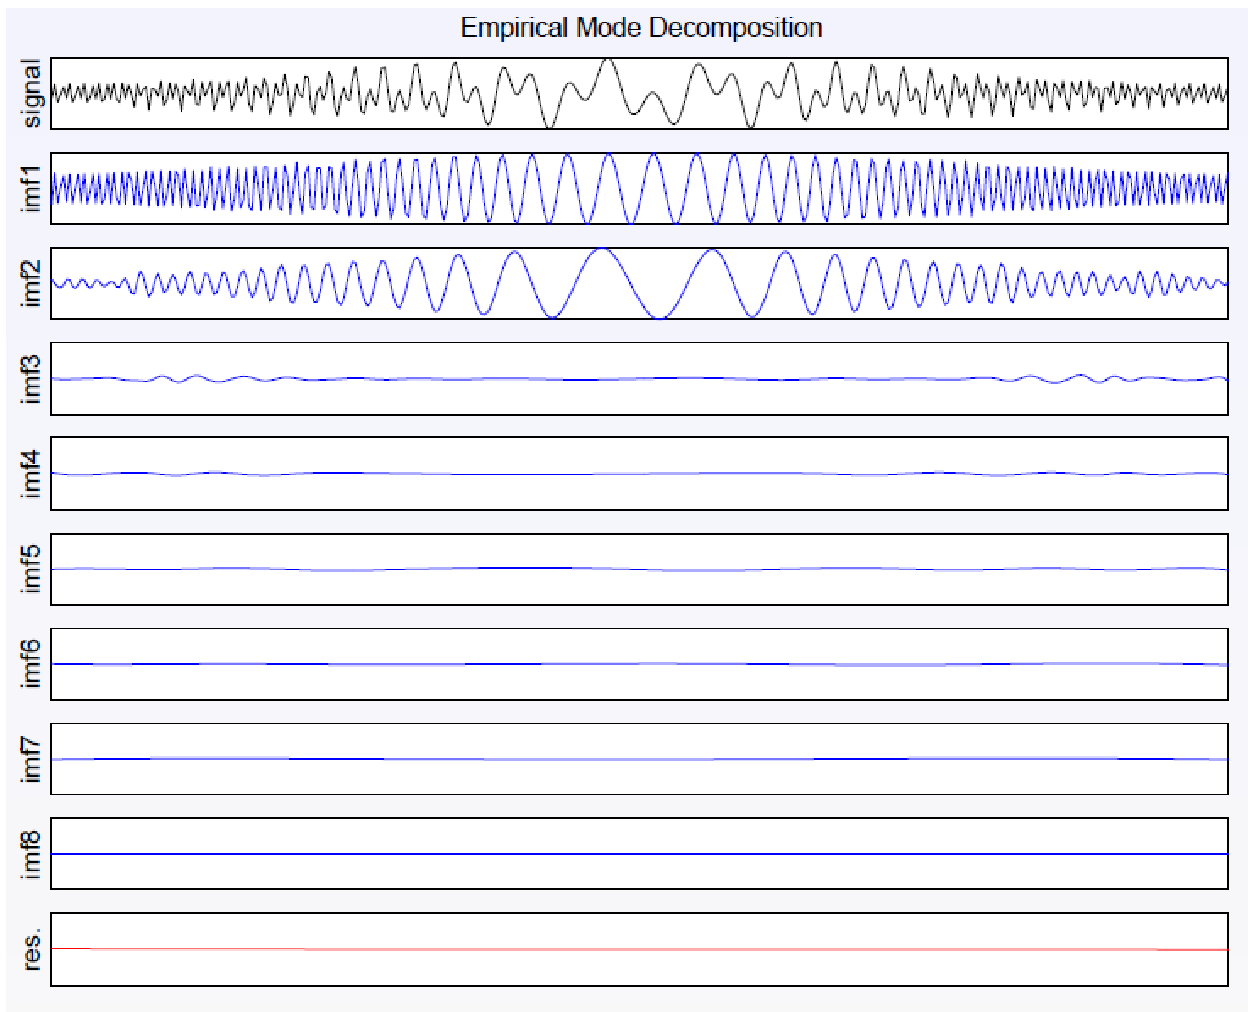
5-بررسی شود که آیا سیگنال حاصل ،شروط لازم IMF بودن را دارد یا خیر؟در صورت داشت به عنوان IMF معرفی شده و در غیر این صورت به مرحله 1 بازگشته و دوباره مراحل الگوریتم را طی میکنیم.

بعد از محاسبه ی اولین IMF ،این تابع از سیگنال اولیه کسر و مقدار باقی مانده محاسبه میشود.

برای استخراج IMF مراحل بالاتر ،الگوریتم Sifting Process بر روی باقی مانده مرحله قبل ادامه میابد.

این فرآیند را تا زمانی که مقدار باقیمانده دارای حداقل دو اکسترمم باشد، ادامه می دهیم.

پس از محاسبه ی تمامی IMF ها میتوانیم با جمع همگی آنها با یکدیگر و باقی مانده ی نهایی به سیگنال اولیه برسیم.



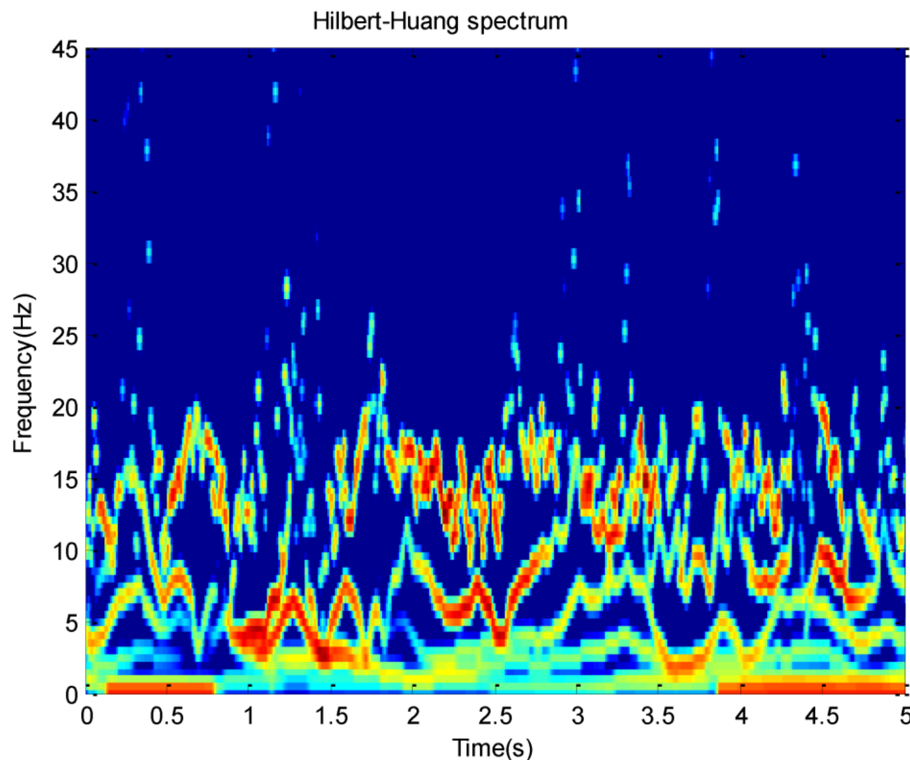
جهت نمایش IMFها در فضای زمان فرکانسی از تبدیل هیلبرت-هوانگ[2] استفاده میکنیم.

در تبدیل هیلبرت-هوانگ، تبدیل هیلبرت بر IMF های حاصل از EMD اعمال میشود.

تبدیل هیلبرت سیگنال دلخواه $c(t)$ به صورت زیر میباشد:

$$\mathrm{H}\left(c\left(t\right)\right)=\frac{1}{\pi}PV\int_{-\infty}^{+\infty}\frac{c\left(\tau\right)}{t-\tau}d\tau$$

در رابطه ی بالا PV مقدار اساسی اتگرال کوشی است؛در واقع تبدیل هیلبرت کانوالو سیگنال $c(t)$ نسبت به تابع 1/t است که نشان دهنده ی تاکید تبدیل هیلبرت بر ویژگی های محلی سیگنال منجمله دامنه و فرکانس لحظه ای می باشد.



از مشکلات آنالیز EMD میتوان به حساس بودن به نویز و تخلیط IMF ها و اثر لبه اشاره کرد.

برای کم کردن اثر لبه بر روی IMF ها ،از روش Local EMD استفاده میکنیم ،این روش همانند EMD به استخراج IMF ها میپردازد با این تفاوت که سیگنال را ابتدا قسمت بندی کرده و سپس IMF ها را محاسبه میکنیم.

[2] *Hilbert–Huang transform* (HHT)

References

1. Akbari, H., M.T. Sadiq, and A.U. Rehman, Classification of normal and depressed EEG signals based on centered correntropy of rhythms in empirical wavelet transform domain. Health Information Science and Systems, 2021. 9(1): p. 1-15.

2. Akbari, H. and M.T. Sadiq, Classification of Seizure and Seizure Free EEG Signals Based on second-order difference plot of DWT coefficients. 2020.

3. Akbari, H., Classification of Seizure and Seizure Free EEG Signals using Geometrical features derived from Poincaré plot, and binary particle swarm optimization.

4. Akbari, H., S.S. Esmaili, and S.F. Zadeh, Classification of seizure and seizure-free EEG signals based on empirical wavelet transform and phase space reconstruction. arXiv preprint arXiv:1903.09728, 2019.

5. Ghofrani, S. and H. Akbari. Comparing nonlinear features extracted in EEMD for discriminating focal and non-focal EEG signals. in Tenth International Conference on Signal Processing Systems. 2019. International Society for Optics and Photonics.

6. Akbari, H. and M.T. Sadiq, Detection of focal and non-focal EEG signals using non-linear features derived from empirical wavelet transform rhythms. Physical and Engineering Sciences in Medicine: p. 1-15.

7. Akbari, H., S. Saraf Esmaili, and S. Farzollah Zadeh, Detection of Seizure EEG Signals Based on Reconstructed Phase Space of Rhythms in EWT Domain and Genetic Algorithm. Signal Processing and Renewable Energy, 2020. 4(2): p. 23-36.

8. Akbari, H. and S. Ghofrani, Fast and accurate classification f and nf EEG by using sodp and EWT. International Journal of Image, Graphics and Signal Processing (IJIGSP), 2019. 11(11): p. 29-35.

9. Hussain, W., et al., Epileptic seizure detection using 1 D-convolutional long short-term memory neural networks. Applied Acoustics, 2021. 177: p. 107941.

10. Sadiq, M.T., X. Yu, and Z. Yuan, Exploiting dimensionality reduction and neural network techniques for the development of expert brain–computer interfaces. Expert Systems with Applications. 164: p. 114031.

11. Sadiq, M.T., et al., Identification of Motor and Mental Imagery EEG in Two and Multiclass Subject-Dependent Tasks Using Successive Decomposition Index. Sensors, 2020. 20(18): p. 5283.

12. Sadiq, M.T., et al., A Matrix Determinant Feature Extraction Approach for Decoding Motor and Mental Imagery EEG in Subject Specific Tasks. IEEE Transactions on Cognitive and Developmental Systems, 2020.

13. Sadiq, M.T., et al., Motor imagery BCI classification based on novel two-dimensional modelling in empirical wavelet transform. Electronics Letters, 2020.

14. Sadiq, M.T., et al., Motor imagery EEG signals classification based on mode amplitude and frequency components using empirical wavelet transform. IEEE Access, 2019. 7: p. 127678-127692.

15. Sadiq, M.T., et al., Motor Imagery EEG Signals Decoding by Multivariate Empirical Wavelet Transform-Based Framework for Robust Brain–Computer Interfaces. IEEE Access, 2019. 7: p. 171431-171451.

16. Arianpour, Y., S. Ghofrani, and H. Amindavar. Locally nonlinear regression based on kernel for pose-invariant face recognition. in 2012 11th International Conference on Information Science, Signal Processing and their Applications (ISSPA). 2012. IEEE.

17. Sharma, M. and U.R. Acharya, Automated detection of schizophrenia using optimal wavelet-based l1 norm features extracted from single-channel EEG. Cognitive Neurodynamics, 2021: p. 1-14.

18. Sharma, M., et al., An automated diagnosis of depression using three-channel bandwidth-duration localized wavelet filter bank with EEG signals. Cognitive Systems Research, 2018. 52: p. 508-520.

19. Sharma, M., et al., An automatic detection of focal EEG signals using new class of time–frequency localized orthogonal wavelet filter banks. Knowledge-Based Systems, 2017. 118: p. 217-227.

20. Sharma, M., et al., Dual-tree complex wavelet transform-based features for automated alcoholism identification. International Journal of Fuzzy Systems, 2018. 20(4): p. 1297-1308.

21. Sharma, M., R.B. Pachori, and U.R. Acharya, A new approach to characterize epileptic seizures using analytic time-frequency flexible wavelet transform and fractal dimension. Pattern Recognition Letters, 2017. 94: p. 172-179.

22. Sharma, M. and R.B. Pachori, A novel approach to detect epileptic seizures using a combination of tunable-Q wavelet transform and fractal dimension. Journal of Mechanics in Medicine and Biology, 2017. 17(07): p. 1740003.

23. Sharma, M., D. Deb, and U.R. Acharya, A novel three-band orthogonal wavelet filter bank method for an automated identification of alcoholic EEG signals. Applied Intelligence, 2018. 48(5): p. 1368-1378.